

基于正则先验的全变差快速代数迭代算法及其在火焰辐射测量中的重建性能分析

李明杰^{1,2}, 贺铸^{1,2*}

¹ 武汉科技大学耐火材料与冶金国家重点实验室, 湖北 武汉 430081;

² 武汉科技大学材料与冶金学院, 湖北 武汉 430081

摘要 针对传统重建算法对火焰重建精度低、重建速度慢的问题, 提出了基于正则先验的全变差代数迭代 (ARTTV) 算法, 以提高对称与非对称火焰的重建精度。同时, 为了提高重建速度, 建立了基于“ARTTV-粒子群算法 (PSO) 内核”的极限学习机 (ELM) 神经网络, 该神经网络具有与迭代算法近乎相同的重建能力, 同时又具有超过迭代算法约 300 倍的重建速度。

关键词 测量; 辐射层析重建; 非对称火焰; 迭代算法; 神经网络

中图分类号 TP391.41

文献标识码 A

doi: 10.3788/AOS201939.1012002

Regularization Priori Based Fast ARTTV Algorithm and Its Reconstruction Performance Analysis During Flame Radiation Measurement

Li Mingjie^{1,2}, He Zhu^{1,2*}

¹ State Key Laboratory of Refractories and Metallurgy, Wuhan University of Science and Technology, Wuhan, Hubei 430081, China;

² College of Material and Metallurgy, Wuhan University of Science and Technology, Wuhan, Hubei 430081, China

Abstract Aiming at the problems of low precision and slow speed of the traditional reconstruction algorithms, we propose a regularization priori based fast all variation algebraic iteration (ARTTV) algorithm to improve the reconstruction precision of the symmetric and asymmetric flames. Further, to improve the reconstruction speed, we establish an extreme learning machine neural network based on the “ARTTV-particle swarm algorithm kernel”, which exhibits approximately the same reconstruction ability as that of the iterative algorithm. The construction speed of the proposed algorithm is approximately 300 times that of the iterative algorithm.

Key words measurement; radiation tomography reconstruction; asymmetric flame; iterative algorithm; neural network

OCIS codes 120.5630; 100.3010; 100.3190

1 引 言

燃烧诊断技术的发展是影响动力装置热工性能和大型炉窑加热性能的关键因素。现有的检测技术主要有相干反斯托克斯拉曼光谱法^[1] (CARS)、激光诱导炽光法^[2] (LII) 和激光荧光光谱法^[3] (LIF), 这些检测技术虽然能够实现对火焰的测量, 但由于这些技术所依托的设备成本高昂、空间布置困难, 无法在工业实际测量中得到广泛推广。

近年来, 层析重建技术以其良好的重建能力已经在医学成像^[4]、燃烧温度诊断^[5]、吸收光谱测量^[6]、电容层析测量^[7]、电阻层析成像^[8]等领域得到了一定发展, 获得了学者们的广泛关注。辐射层析方法的优点是结构简单、成本低廉、可进行三维 (3D) 实时在线测量。但是, 受限于传统重建算法所面临的计算精度和计算速度难以权衡的问题, 层析重建技术在实际生产中的应用依然面临很多困难。

用主流算法反演火焰目标时, Tikhonov 正则化

收稿日期: 2019-03-06; 修回日期: 2019-05-31; 录用日期: 2019-06-21

基金项目: 国家自然科学基金青年项目 (51404176)

* E-mail: hezhu@wust.edu.cn

算法^[9]和 LSQR(least squares QR decomposition) 算法^[10]虽然计算速度较快,但对非对称对象难以实现高精度测量,且对噪声的抑制能力较弱。以迭代计算为代表的代数迭代算法^[11](ART)虽然能够保证反演精度,但大量的迭代计算严重延长了重建时间,导致其无法在工业中进行实时测量。从本质上来讲,这是算法在重建精度和重建速度上的权衡问题。近年来,为了探求重建算法在精度上的进一步提高,Sidky 等^[12]提出了基于正则先验的全变差快速代数迭代(ARTTV)算法,该算法在稀疏角度下对非对称对象的测量可以达到较高的精度。Cai 等^[13]利用基于 TV(total variation)平滑的 RART(regularization of ART)算法进行了非轴对称火焰的重建研究,结果表明:在附加 5%高斯噪声的条件下,该算法依然可以获得相对误差为 5.38%的重建结果。Zhang 等^[14]利用全变分最小化方法改善了不完全投影下的目标火焰的重建精度。从上述研究工作中可以发现:ARTTV 算法能够在 ART 算法的基础上进一步利用目标物理场的稀疏信息提升反演精度。

为了解决重建算法精度和速度的双重问题,本文分两步走:第一步,提出一种基于正则先验的 ARTTV 算法,其火焰物理场的先验信息通过 LSQR 算法预先获得,正则因子通过粒子群(PSO)算法全局寻优获得,正则参数的最优化解提升了 ARTTV 算法输出的鲁棒性和精确性;第二步,为了解决算法重建速度慢的问题,提出利用极限学习机(ELM)神经网络^[15]的非线性拟合能力来近似逼近 ARTTV-PSO 算法,借助 ELM 的高效计算间接实现快速反演。2015 年,Liu 等^[16]提出了一种基于 ELM 和 Landweber 迭代的算法完成了电容层析成像。2018 年,Yu 等^[17]通过给定虚拟火焰样本的方法验证了 ELM 神经网络对多峰分布型火焰的反演效果。但是,上述研究依然没有解决 ELM 神经网络对检测目标训练样本的采集问题。如果不提供高精度的样本数据或样本质量较差,ELM 神经网络本身是无法解决辐射反问题的,也无法解决大型稀疏矩阵的不稳定问题。基于以上情况,本文将 ARTTV-PSO 作为 ELM 神经网络的“处理内核”,以达到重建能力“移植”的目的,最终实现重建速度的大幅提升。

2 理论与方法

2.1 火焰边界强度投影方程

具有辐射特性的烟黑颗粒在火焰中沿射线方向

可以发射辐射能,利用电荷耦合器件(CCD)传感器获得该辐射能后,就能够通过重建算法获得火焰断层截面内的辐射源项分布、温度分布、烟黑体积分数分布,投影重建过程示意图如图 1 所示。由于碳氢火焰生成的烟黑颗粒的粒径尺度为纳米级,在 380~780 nm 可见光波长范围内,其内部吸收和散射可以忽略^[18-19]。在指定的多个谱线下,沿任意投影方向的光强积分值,即边界处光谱仪获得的单色辐射强度 B_λ 可以表示为

$$B_\lambda = \int_{l_0}^{l_1} k_\lambda(l) I_{\text{ba}}(l) dl, \quad (1)$$

式中: B_λ 为火焰边界处通过光谱传感器采集得到的光谱辐射强度; k_λ 为颗粒吸收系数; l 为 $N \times N$ 计算域内的积分(起始)路径, N 为计算域边长的网格数量; I_{ba} 为黑体光谱辐射强度; λ 为对应的波长谱线; l_0 和 l_1 为入射光强与计算域相交的起始点和终点。若传感器为 CCD,则(1)式需要在特定红(R)/绿(G)/蓝(B)谱带下积分,以获得特定谱带范围的辐射强度。(1)式可转化为矩阵乘积的形式,即

$$B_\lambda = A \cdot H_\lambda, \quad (2)$$

式中: A 为投影系数矩阵, A 中的任意元素表示的是对应网格中的元素对边界积分投影的贡献,而元素的大小则定义为射线与网格两个交点的线段长度; H_λ 为对应谱线 λ 下的本地辐射源项。由于每条射线穿过整个计算域时仅与几个网格有交集,因此矩阵 A 实际上是大型稀疏矩阵,需要运用不稳定矩阵求解算法才能获得合理的反演结果。




图 1 辐射投影重建示意图

Fig. 1 Diagram of radiation projection reconstruction

2.2 ARTTV 算法

最早在 20 世纪 70 年代 Gordon 等^[20]就将 ART 引入到了图像重建领域。其基本思想是:给定一个初值,再将所得到的投影残差沿其射线方向逐一进行逆向反投影,同时不断地校正图像函数值,直

到满足迭代终止条件,其所遵循的公式为

$$\mathbf{f}^k = \mathbf{f}^{k-1} + \beta \mathbf{M}_i^T \frac{p_i - \mathbf{M}_i \mathbf{f}^{k-1}}{\mathbf{M}_i \mathbf{M}_i^T}, \quad (3)$$

式中: \mathbf{f}^k 为第 k 次的迭代值,当方形计算域边长为 n 时, $\mathbf{f}^k \in n^2 \times 1$; β 为松弛因子,选取 0.85; k 为当前迭代次数; \mathbf{M}_i 为第 m 个投影角度下对应投影系数矩阵 \mathbf{A} 中的第 i 行元素; \mathbf{M}_i^T 为 \mathbf{M}_i 的转置,其中, $i \leq n$, $\mathbf{M}_i \in 1 \times n^2$; p_i 为边界辐射强度列向量中的第 i 个元素,为标量。但是,当对投影数据在有限角度(稀疏角度)条件下采样时,即使增加迭代次数也无法得到满足精度要求的结果。因此,需要利用先验信息来提高重建精度。

全变分稀疏最小化方法可以利用相邻区域内物理量的梯度信息,其实现思想是:在满足积分投影方程的前提下,寻找(3)式的最小稀疏解的过程^[21],即

$$\min \|\mathbf{f}\|_{\text{TV}} \quad \text{s.t.} \quad \mathbf{A}\mathbf{f} = \mathbf{B}, \quad (4)$$

式中: \mathbf{A} 为投影系数矩阵, $\mathbf{A} \in n \times n^2$; \mathbf{B} 为边界投影强度列向量, $\mathbf{B} \in mn \times 1$ 。由于(4)式为非凸优化问题,难以求解,通常需要将 TV 范数转化为 L2 范数并通过最速下降法来寻优求解。同时,需要引入一个很小的正数 ϵ ,以防对 $V_{\text{TV}}(\mathbf{f})$ 求导后产生无穷大的错误,取 $\epsilon = 1 \times 10^{-6}$ 。 $V_{\text{TV}}(\mathbf{f})$ 表达式为

$$V_{\text{TV}}(\mathbf{f}) = \sum_{s,t} (|f_{s,t} - f_{s-1,t}| + |f_{s,t} - f_{s,t-1}|) \approx \sum_{s,t} \sqrt{(f_{s,t} - f_{s-1,t})^2 + (f_{s,t} - f_{s,t-1})^2 + \epsilon}, \quad (5)$$

式中: $f_{s,t}$ 为矩阵中索引号为 (s, t) 的单元格内的具体数值; s, t 为计算域离散网格的索引编号。(5)式的物理意义是:通过搜索待求未知量 \mathbf{f} 在相邻各元素的四方向梯度全局最小值,将其作为先验条件约束整个 ART 的迭代过程。

2.3 基于正则先验的 ARTTV 算法

传统的 ARTTV 算法将 ART 算法每一次迭代的反演结果作为 TV 计算的初值,再通过最速下降法^[22] 获得梯度稀疏极值,再由 ART 进行循环迭代计算,此重建过程并没有受被测目标先验信息的指导。为此,利用 LSQR 方法,将求解得到的“预结论”作为先验信息,并将 ART 算法每一步迭代值与先验信息的差值作为 TV 最小稀疏运算的迭代变量,该差值矩阵即为迭代过程的正则约束项。TV 迭代变量 \mathbf{f}_{TV} 的表达式为

$$\mathbf{f}_{\text{TV}} = \mathbf{f}_{\text{ART}} + \alpha \|\mathbf{f}_{\text{ART}} - \mathbf{M}_z\|, \quad (6)$$

式中: $\|\cdot\|$ 为取正值操作; \mathbf{f}_{ART} 为 ART 算法输出的原始计算值; \mathbf{M}_z 为用 LSQR 算法获得的目标辐射场

的先验信息,LSQR 算法的实现方法详见文献[23]; α 为正则因子,控制先验信息对目标方程的权重关系。由此,ARTTV 先验正则化算法的迭代变量 \mathbf{f}_{iter} 为

$$\mathbf{f}_{\text{iter}} = \operatorname{argmin}(\mathbf{f}_{\text{TV}}) = \operatorname{argmin}(\mathbf{f}_{\text{ART}} + \alpha \|\mathbf{f}_{\text{ART}} - \mathbf{M}_z\|). \quad (7)$$

2.4 PSO 对正则参数寻优

上文提到的正则化因子在迭代过程中起到了控制正则项权重的作用,非最优正则因子会影响重建精度,因此本文提出利用 PSO 算法的全局寻优能力来获得正则因子的最优解。PSO 算法是一种根据鸟类觅食概念产生的群优化参数搜索方法,在 PSO 算法中将每个粒子的位置作为未知量,在搜索域中的粒子速度通过个体最优位置和全局最优位置的变化不断地被更新。对于标准 PSO 算法^[24],粒子速度 \mathbf{v}_{oj} 和位置 \mathbf{x}_{oj} 的迭代公式为

$$\begin{aligned} \mathbf{v}_{oj}(t+1) &= \psi \mathbf{v}_{oj}(t) + c_1 r_1 [\mathbf{p}_{oj}(t) - \mathbf{x}_{oj}(t)] + \\ &\quad c_2 r_2 [\mathbf{p}_g(t) - \mathbf{x}_{oj}(t)] \\ \mathbf{x}_{oj}(t+1) &= \mathbf{x}_{oj}(t) + \mathbf{v}_{oj}(t+1), \end{aligned} \quad (8)$$

式中: t 为迭代次数,下标 o 表示第 o 个种群;下标 j 表示第 j 次迭代; ψ 为速度权重因子; r_1 和 r_2 为 $(0 \sim 1)$ 内的随机数; c_1 和 c_2 为学习因子,分别控制每个粒子朝着本地和全局最优方向移动的程度,通常取值范围为 $1 \sim 2$,这里取 $c_1 = 1.5, c_2 = 1.8$; \mathbf{p}_{oj} 为本地最佳位置; \mathbf{p}_g 为全局最佳位置。

利用 PSO 算法估计正则因子的步骤如下:

1) 初始化颗粒种群规模 S 、初始计算参数和学习因子,即 $S = 60$,寻优范围为 $0 \sim 10$,最大搜索速度为 $S/5$ 。

2) 计算目标方程的值,并更新颗粒位置。目标方程 R 为

$$R = \sqrt{\frac{1}{\text{SQ}} \sum_{r=1}^{\text{SQ}} [\mathbf{B}_\lambda(r) - \mathbf{B}_{\lambda,\text{mea}}(r)]^2}, \quad (9)$$

式中: Q 为波长数量; \mathbf{B}_λ 为边界光强的计算值; $\mathbf{B}_{\lambda,\text{mea}}$ 为通过 CCD 传感器获得的实测值或边界投影积分计算值[根据(1)式]; r 为每个波长下所有种群粒子的索引。

3) PSO 算法每次通过比较目标方程的最优值来更新最佳正则化因子。如果计算已达到最大迭代次数或迭代多次后最优解未改善,则转到步骤 4); 否则,计算新颗粒速度并使用(8)式更新粒子位置,并循环到步骤 2)。

4) 输出最优值。

将 PSO 优化后的重建算法命名为 ARTTV-

PSO,具体的重建计算的流程如下:

1) 初始化计算域网格参数、投影角度数、迭代终止条件、PSO 迭代次数、种群规模、高斯噪声量级等。

2) 利用 ART 算法获得迭代解,并进行非负约束,根据(3)式完成计算。

3) 利用 LSQR 获得先验信息,根据(4)~(5)式求解目标差值矩阵的最小稀疏解,并将其作为 ART 算法下一次的迭代变量。其中,正则化因子可利用 PSO 算法求解获得。当结果满足重建精度(误差小于 1×10^{-6})或最大迭代次数(100 次)时停止计算,输出结果。需要注意的是,在真实实验中,待测物理量的真实分布未知。因此,迭代收敛的条件需要修改为相邻两次迭代偏差不再增大(或保持恒定不变),即认为计算已达到收敛,或者设定最大迭代次数,当满足最大迭代次数后停止计算。

2.5 ELM 神经网络方法

ELM 神经网络可以看成是一个拟合输入与输出关系的“黑盒子”。它的权值不需要像反向传播(BP)神经网络那样通过误差的反向传播获得。数学上,它的结构可以表示成

$$\mathbf{G}(\mathbf{w}, \mathbf{P}, \mathbf{b})\boldsymbol{\chi} = \mathbf{F}, \quad (10)$$

$$\mathbf{G}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_n, b_1, b_2, \dots, b_n, P_1, P_2, \dots, P_q) = \begin{bmatrix} g(\mathbf{w}_1 P_1 + b_1) & \dots & g(\mathbf{w}_n P_1 + b_n) \\ \vdots & & \vdots \\ g(\mathbf{w}_1 P_q + b_1) & \dots & g(\mathbf{w}_n P_q + b_n) \end{bmatrix}_{q \times n}, \quad (11)$$

式中: \mathbf{G} 为隐含层的输出矩阵; \mathbf{w} 和 \mathbf{b} 分别为网络连接的权值和阈值;下标 n 为隐含层节点的个数,它们均随机设定; g 为非线性激活函数,这里采用 Sigmoid 函数; \mathbf{P} 为输入样本,对应火焰反演问题中的边界辐射强度列向量;下标 q 为样本个数; \mathbf{F} 为神经网络的输出向量,对应需要重建的本地辐射源项矩阵; $\boldsymbol{\chi}$ 为隐含层与输出层的连接矩阵,可一次求解完成。 $\boldsymbol{\chi}$ 的表达式为

$$\boldsymbol{\chi} = \mathbf{G}^\dagger \mathbf{F}, \quad (12)$$

式中: \mathbf{G}^\dagger 为 \mathbf{G} 的伪逆矩阵。训练样本的获取是利用 ARTTV 算法输出 \mathbf{P} 和 \mathbf{F} ,并将其作为训练样本集,当网络训练完成后,它就能够具备与 ARTTV 算法几乎相同的重建能力,同时也获得了重建速度的提升。

具体实现步骤如下:

在网络训练过程中,首先随机初始化网络参数 \mathbf{w}, \mathbf{b} ;然后利用 ARTTV-PSO 算法提供样本数据,

隐藏层的矩阵 \mathbf{G} 可以由(11)式求解,而 \mathbf{G}^\dagger 可以通过求解 \mathbf{G} 的伪逆矩阵来获得;最后,连接矩阵 $\boldsymbol{\chi}$ 可以根据(12)式计算得到。此时,网络训练过程结束,网络权重参数 \mathbf{w}, \mathbf{b} 被最终确定。在测试过程中,需要再次从测试集样本中计算 \mathbf{G} 和 \mathbf{G}^\dagger 矩阵;然后直接计算 $\mathbf{G}\boldsymbol{\chi}$,获得最终的重建结果。

2.6 重建结果评估标准

为了测试算法的抗噪能力,边界强度被人为地加入不同量级的随机高斯噪声,其关系满足

$$\mathbf{B}'_\lambda = \mathbf{B}_\lambda (1 + \sigma \xi), \quad (13)$$

式中: \mathbf{B}'_λ 为附加高斯随机噪声后的边界光谱辐射强度; \mathbf{B}_λ 为初始边界光谱辐射强度; σ 为高斯误差均方差; ξ 为标准正态分布的随机变量。相对均方误差 E_{rr} 定义为

$$E_{rr} = \frac{\left[\frac{1}{N^2} \sum_{u=1}^{N^2} (\mathbf{H}_{\text{recons},u} - \mathbf{H}_{\text{original},u})^2 \right]^{\frac{1}{2}}}{f_{\max}(\mathbf{H}_{\text{original}})}, \quad (14)$$

式中: N^2 为断层截面的计算域的网格数量; $\mathbf{H}_{\text{recons},u}$ 和 $\mathbf{H}_{\text{original},u}$ 分别为重建结果和原始目标值;下标 u 为计算域每个网格元素的索引值; f_{\max} 为求最大值函数。

3 结果与讨论

为了测试算法对不同火焰类型的重建效果,引入了非预混乙烯轴对称型单峰分布辐射源项^[25]、高斯型双峰分布(图 2)以及虚拟三峰分布辐射源项来测试所提算法的重建精度,原始三峰目标火焰的辐射源项如图 3 所示。模拟仿真中分别使用 ARTTV-PSO 算法、Tikhonov 正则化算法、LSQR 算法测试重建了上述轴对称和非轴对称火焰的辐射源项分布。之后,经 ELM 神经网络优化后,对其进行双峰目标反演测试,并评估反演的精度和速度。在计算中,投影角度数量均为 60 个。迭代终止条件为达到最大迭代次数(100 次)或者相对误差小于 1×10^{-6} 。在训练样本生成计算中,使用图形处理器(GPU)加速技术^[26]。模拟计算硬件平台为 CPU i7 3.4G, 16 GB RAM GPU 为 GTX 1080Ti。软件为 MATLAB 2017b。

3.1 轴对称型火焰的重建效果

为了测试算法的抗噪性,边界强度被附加了 3% 的高斯噪声。断层截面的计算域被离散成 63×63 的网格区域。提取轴对称目标火焰在 25, 35, 45 mm 这 3 个断层高度 H 处的数据作为反演测试对象。两种算法在 3 个高度下的反演结果如图 4 所示。




图 2 原始高斯型双峰辐射源项分布。(a) 3D 空间-强度显示;(b) 二维(2D)空间-色带强度显示
Fig. 2 Distributions of original Gaussian bimodal radiation source. (a) 3D space-intensity display;
(b) 2D space-ribbon intensity display

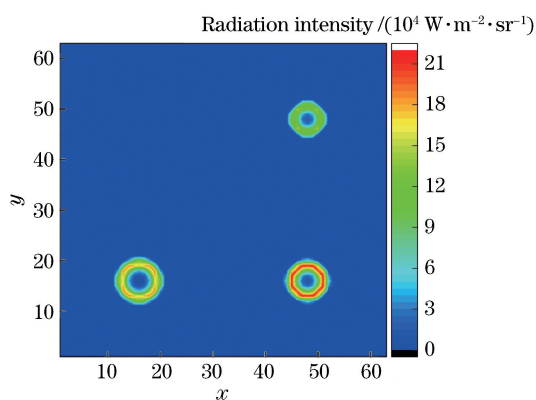


图 3 原始三峰目标火焰的辐射源项
Fig. 3 Radiation intensity of original three-peak target flame

由图 4 可以看出:在 3 个高度下,所提 ARTTV-PSO 算法的全局均方差都小于正则化算法;在靠近峰值的区域,两种算法的重建精度相近,但 ARTTV-PSO 算法在低强度区域的反演噪声显然更小。因此,总体上来说,在外部误差为 3% 的情况下,所提算法在峰值附近区域的精度与经典 Tikhonov 正则化算法相近,但在低强度区的反演抗

噪性方面,ARTTV-PSO 算法更强。

3.2 高斯双峰型火焰的重建效果

利用高斯函数生成了双峰型辐射源项分布。边界辐射强度被附加了 1% 的高斯噪声,目的是测试算法的抗噪性。断层截面的计算区域被离散成 61×61 的网格区域。将所提算法与 Tikhonov 正则化、LSQR 算法进行比较,结果如图 5 所示。从全局均方差来看,所提算法的重建精度要远远高于其他两种算法。具体来说,正则化算法重建结果的伪影十分严重,且无法还原初始目标的形状;ARTTV-PSO 的重建结果几乎无伪影,且对不同区域辐射(色带)强度的还原程度非常高;LSQR 算法的精度介于上述两者之间。因此,可以说在含有 1% 外部高斯噪声的情况下,ARTTV-PSO 算法对该双峰型火焰的重建能力要远远高于传统的正则化算法和 LSQR 算法。同时,ARTTV-PSO 算法还具有更高的抗噪能力和抑制伪影的能力。

3.3 虚拟三峰火焰源项分布的重建效果

在对虚拟三峰火焰的模拟测试中,边界辐射强




图 4 不同算法对轴对称单峰火焰在不同断层高度处的重建结果。(a) $H=25$ mm;(b) $H=35$ mm;(c) $H=45$ mm
Fig. 4 Reconstruction results of different symmetry single-peak flames at different fault heights for different algorithms.
(a) $H=25$ mm;(b) $H=35$ mm;(c) $H=45$ mm




图 5 不同算法对高斯双峰辐射分布的重建结果。(a) ARTTV-PSO; (b) LSQR; (c) 正则化算法

Fig. 5 Reconstruction results of Gaussian bimodal radiation intensity distributions for different algorithms.

(a) ARTTV-PSO; (b) LSQR; (c) regularization algorithm

度依然被附加了 3% 的高斯噪声。图 6 为不同算法对三峰辐射强度源项的重建结果。由图 3 和图 6 可知:3 种算法重建精度的对比情况与反演双峰火焰的结果类似。ARTTV-PSO 算法得到的结果依然是无任何伪影产生,且几乎重现了原始三峰分布的完整形状,重建相对误差为 2.17%,是 3 种算法中最

低的。这说明 ARTTV-PSO 算法对非对称目标具有较高的重建能力。反观另外两种算法,它们得到的结果都具有相当多的伪影,且无法正确还原目标外轮廓,说明这两种传统算法并不适合用于解决非对称目标的重建。




图 6 不同算法对于三峰辐射强度源项的重建结果。(a) LSQR; (b) 正则化算法; (c) ARTTV-PSO

Fig. 6 Reconstruction results of three-peak radiation intensity distributions obtained by different algorithms.

(a) LSQR; (b) regularization algorithm; (c) ARTTV-PSO

3.4 ELM 神经网络实现快速重建的效果

虽然所提 ARTTV-PSO 算法具有良好的重建能力和抗噪性,但其大量的迭代计算非常耗时,每一个火焰断层高度的模拟计算都需要约 320 s 的时间,这使得该重建技术难以应用在需要实时测量的工业环境中。为此,采用 ELM 神经网络对 ARTTV-PSO 算法进行近似逼近,目的是使 ELM 神经网络具有与 ARTTV-PSO 算法相同的重建能力,同时还能大幅提高重建速度。以双峰型火焰辐射源项分布为测试对象,该双峰型火焰由单峰火焰组合构建而成,每个单峰火焰高度均分为 1~50 mm,因此该双峰型火焰可以组合获得 2500 个火焰断层的原始数据。从中随机抽取 500 个数据作为训练样本,利用 ARTTV-PSO 算法反演获得对应样

本的重建结果,每个样本数据的网格规模为 63×63 ,将其作为训练集输入到 ELM 神经网络中完成训练过程。从剩下的 2000 个断层火焰数据中任取一个作为测试目标,评估 ELM 神经网络的重建效果。结果如图 7 所示。

由图 7 可知:ELM 神经网络可以非常精确地还原 ARTTV-PSO 的重建结果,两个测试目标下的相对误差分别为 0.37% 和 0.48%,说明 ELM 神经网络具有极高的非线性拟合能力。同时,ELM 神经网络的样本训练和重建计算的总时间为 1 s,这意味着 ELM 神经网络的重建速度比 ARTTV-PSO 算法提高了约 300 倍。综上所述,使用基于“ARTTV-PSO 内核”的 ELM 神经网络来重建非对称双峰火焰目标,可以在提高 300 倍重建速度的同时仅损失

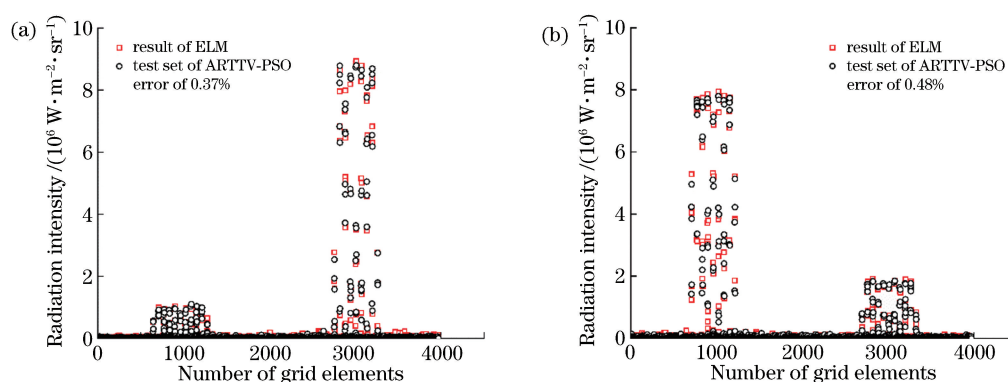


图7 ELM神经网络重建双峰分布辐射强度源项的结果。(a)测试火焰1; (b)测试火焰2

Fig. 7 Reconstruction results of bimodal radiation intensity distributions of ELM neural network.

(a) Test flame 1; (b) test flame 2

0.5%左右的重建精度。这一技术为实际工业中的实时测量提供了良好的技术尝试。

4 结 论

提出了一种基于正则先验的 ARTTV 算法来对轴对称和非轴对称火焰的辐射源项进行数值重建。正则化参数采用基于 PSO 的寻优算法来获得。通过模拟仿真发现:与传统算法相比,所提 ARTTV-PSO 算法对非轴对称对象具有更高的重建精度;而对于轴对称对象,在峰值附近区域,ARTTV-PSO 算法的精度与传统重建算法相近,但在低强度区域范围内,该算法具有更好的抗噪性,且全局反演精度更高。此外,为了提高重建速度,构建了基于“ARTTV-PSO 内核”的 ELM 神经网络。模拟测试结果表明,基于 ELM 神经网络优化后的重建算法具有比原 ARTTV-PSO 算法快 300 倍的重建速度,且仅需损失约 0.5% 的重建精度,这说明所提重建算法已具备工业化实时测量的能力。

参 考 文 献

- [1] Tolles W M, Nibler J W, McDonald J R, *et al.* A review of the theory and application of coherent anti-Stokes Raman spectroscopy (CARS) [J]. *Applied Spectroscopy*, 1977, 31(4): 253-271.
- [2] Lou C, Chen C, Sun Y P, *et al.* Review of soot measurement in hydrocarbon-air flames [J]. *Scientia Sinica(Technologica)*, 2010, 40(8): 946-958.
娄春, 陈辰, 孙亦鹏, 等. 碳氢火焰中碳黑检测方法评述 [J]. *中国科学:技术科学*, 2010, 40(8): 946-958.
- [3] Rensberger K J, Jeffries J B, Copeland R A, *et al.* Laser-induced fluorescence determination of temperatures in low pressure flames [J]. *Applied Optics*, 1989, 28(17): 3556-3566.
- [4] Liu J, Kang Y Q, Gu Y B, *et al.* Sparse tensor constrained for low dose CT reconstruction [J]. *Acta Optica Sinica*, 2019, 39(8): 0811004.
刘进, 亢艳芹, 顾云波, 等. 稀疏张量约束的低剂量 CT 图像重建 [J]. *光学学报*, 2019, 39(8): 0811004.
- [5] Cheng Q, Zhang X Y, Wang Z C, *et al.* Simultaneous measurement of three-dimensional temperature distributions and radiative properties based on radiation image processing technology in a gas-fired pilot tubular furnace [J]. *Heat Transfer Engineering*, 2014, 35(6/7/8): 770-779.
- [6] Cai W W, Kaminski C F. Tomographic absorption spectroscopy for the study of gas dynamics and reactive flows [J]. *Progress in Energy and Combustion Science*, 2017, 59: 1-31.
- [7] Yang W Q, Peng L H. Image reconstruction algorithms for electrical capacitance tomography [J]. *Measurement Science and Technology*, 2003, 14(1): R1-R13.
- [8] Song X Z, Xu Y B, Dong F. A spatially adaptive total variation regularization method for electrical resistance tomography [J]. *Measurement Science and Technology*, 2015, 26(12): 125401.
- [9] Zhang X Y, Cheng Q, Lou C, *et al.* An improved colorimetric method for visualization of 2-D, inhomogeneous temperature distribution in a gas fired industrial furnace by radiation image processing [J]. *Proceedings of the Combustion Institute*, 2011, 33(2): 2755-2762.
- [10] Liu D, Yan J H, Wang F, *et al.* Experimental reconstructions of flame temperature distributions in laboratory-scale and large-scale pulverized-coal fired furnaces by inverse radiation analysis [J]. *Fuel*, 2012, 93: 397-403.
- [11] Liu L H, Man G L. Reconstruction of time-averaged

- temperature of non-axisymmetric turbulent unconfined sooting flame by inverse radiation analysis [J]. *Journal of Quantitative Spectroscopy and Radiative Transfer*, 2003, 78(2): 139-149.
- [12] Sidky E Y, Pan X C. Image reconstruction in circular cone-beam computed tomography by constrained, total-variation minimization[J]. *Physics in Medicine & Biology*, 2008, 53(17): 4777-4807.
- [13] Cai W W, Li X S, Ma L. Practical aspects of implementing three-dimensional tomography inversion for volumetric flame imaging[J]. *Applied Optics*, 2013, 52(33): 8106-8116.
- [14] Zhang B, Zhao M M, Liu Z G, *et al.* Flame four-dimensional deflection tomography with compressed-sensing-revision reconstruction[J]. *Optics and Lasers in Engineering*, 2016, 83: 23-31.
- [15] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks[C]//2004 IEEE International Joint Conference on Neural Networks, July 25-29, 2004, Budapest, Hungary. New York: IEEE, 2004: 985-990.
- [16] Liu X, Wang X X, Hu H L, *et al.* An extreme learning machine combined with Landweber iteration algorithm for the inverse problem of electrical capacitance tomography[J]. *Flow Measurement and Instrumentation*, 2015, 45: 348-356.
- [17] Yu T, Cai W W, Liu Y Z. Rapid tomographic reconstruction based on machine learning for time-resolved combustion diagnostics [J]. *Review of Scientific Instruments*, 2018, 89(4): 043101.
- [18] Liu D, Yan J H, Cen K F. On the treatment of scattering for three-dimensional temperature distribution reconstruction accuracy in participating medium[J]. *International Journal of Heat and Mass Transfer*, 2011, 54(7/8): 1684-1687.
- [19] Li T J, Li S N, Yuan Y, *et al.* Light field imaging analysis of flame radiative properties based on Monte Carlo method[J]. *International Journal of Heat and Mass Transfer*, 2018, 119: 303-311.
- [20] Gordon R, Bender R, Herman G T. Algebraic reconstruction techniques (ART) for three-dimensional electron microscopy and X-ray photography [J]. *Journal of Theoretical Biology*, 1970, 29(3): 471-481.
- [21] Mo L D, Xu B Q. An improved TV image reconstruction algorithm [J]. *Electronic Science and Technology*, 2016, 29(10): 47-50.
莫礼东, 徐伯庆. 一种改进的 TV 图像重建算法 [J]. *电子科技*, 2016, 29(10): 47-50.
- [22] Guo X C. Unconstrained optimization problems: study on the most rapid descent method and Newton algorithm [J]. *Course Education Research*, 2018 (40): 157, 159.
郭勋诚. 无约束优化问题: 最速下降法和牛顿算法研究 [J]. *课程教育研究*, 2018(40): 157, 159.
- [23] Paige C C, Saunders M A. LSQR: an algorithm for sparse linear equations and sparse least squares[J]. *ACM Transactions on Mathematical Software*, 1982, 8(1): 43-71.
- [24] Shi Y, Eberhart R C. Empirical study of particle swarm optimization [C]//1999 Congress on Evolutionary Computation-CEC99, July 6-9, 1999, Washington, DC, USA. New York: IEEE, 1999: 1945-1950.
- [25] Liu F S, Guo H S, Smallwood G J, *et al.* Numerical modelling of soot formation and oxidation in laminar coflow non-smoking and smoking ethylene diffusion flames [J]. *Combustion Theory and Modelling*, 2003, 7(2): 301-315.
- [26] van Heeswijk M, Miche Y, Oja E, *et al.* GPU-accelerated and parallelized ELM ensembles for large-scale regression [J]. *Neurocomputing*, 2011, 74 (16): 2430-2437.